

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Mislav Biličić

**ODREĐIVANJE DIMENZIJA OBJEKTA SNIMLJENOG
IZ ZRAKA**

DIPLOMSKI RAD

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 5. travnja 2018.

Zavod: **Zavod za aeronautiku**
Predmet: **Zrakoplovno izviđanje i nadzor**

DIPLOMSKI ZADATAK br. 4557

Pristupnik: **Mislav Biličić (0135228283)**
Studij: **Aeronautika**

Zadatak: **Određivanje dimenzija objekta snimljenog iz zraka**

Opis zadatka:

Definirati fotogrametriju, stereoskopiju i objasniti stereoskopsku paralaksu. Isplanirati optimalnu rutu snimanja objekta bespilotnom letjelicom. Provesti snimanje i odrediti obujam objekta koristeći stereoskopsku paralaksu. Klasificirati dijelove površine objekta i odrediti površine pojedinih dijelova. Provesti 5 nezavisnih snimanja i proračuna. Izvršiti statističku analizu rezultata i usporediti sa stvarnim vrijednostima.

Mentor:

Predsjednik povjerenstva za
diplomski ispit:

dr. sc. Jurica Ivošević

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

ODREĐIVANJE DIMENZIJA OBJEKTA SNIMLJENOG IZ ZRAKA

DETERMINATION OF OBJECT DIMENSIONS BY AREAL PHOTOGRAPHY

Mentor: dr. sc. Jurica Ivošević

Student: Mislav Biličić

JMBAG: 0135228283

Zagreb, rujan 2018.

ODREĐIVANJE DIMENZIJA OBJEKTA SNIMLJENOG IZ ZRAKA

SAŽETAK:

Letenje je čovjeku omogućilo novi pogled na svijet. Fotografijama iz zraka moguće je jeftino, brzo i točno mapirati često nedostupna područja. Očuvanjem odnosa među objektima na fotografijama omogućeno je mjerenje dimenzija i udaljenosti. Ono se naziva fotogrametrija i uključuje više načina mjerenja. Promjena perspektive na fotografijama omogućuje mjerenje udaljenosti postupkom stereoskopske paralakse. U radu su stereoskopskom paralaksom određene dimenzije objekta određenog za obnovu. iz fotografija snimljenih iz zraka određene su dimenzije pomoću kojih su izračunate površine klasificiranih dijelova objekta. Analizirana su odstupanja izmjerenih i stvarnih površina te vrsta pogrešaka u mjerenju koje se pojavljuju. Zaključeno je da je pogreška određivanja površina stereoskopskom paralaksom prihvatljiva te se metoda može koristiti za izračun dimenzija objekta snimljenog iz zraka.

KLJUČNE RIJEČI: snimanje iz zraka; fotografija; fotogrametrija; stereoskopska paralaksa, određivanje dimenzija

SUMMARY:

Flying gave men a new look at the world. Using areal photographs it is possible to quickly and precisely map often inadequate areas. By keeping relationships between objects on photographs it is possible to measure dimensions and distances. This is called photogrammetry and includes multiple measurement methods. Changing the perspective of the photographs allows measurement technique called stereoscopic parallax. In this paper parallax will be used to measure dimensions of an abandoned object set for reconstruction. Areal photographs were taken from which dimensions were obtained. Through those dimensions areas were calculated and classified. Deviations between calculated and actual areas were calculated and analyzed. It was concluded that error with stereoscopic parallax is within acceptable range and this method can be used to calculate the dimensions of an object recorded from the air.

KEY WORDS: areal photography; photography; photogrammetry; stereoscopic parallax; measurement

POPIS OZNAKA I MJERNIH JEDINICA

f	frekvencija [Hz]
c	brzina širenja elektromagnetskog vala [m/s]
λ	valna duljina [μm]
h	visina objekta [m]
H	visina leta zrakoplova [m]
a	udaljenost baza objekta [mm]
y	udaljenost baza objekta [mm]
b	udaljenost vrhova objekta [mm]
x	udaljenost centara dviju fotografija [mm]
dp	diferencijska paralaksa [mm]
P	razlika udaljenosti centara fotografija i udaljenosti baza objekta [mm]
H_c	visina po sredini zgrade [m]
H_r	visina ruba [m]
H_v	visina vrata [m]
H_p	visina prozora [cm]
W_{vp}	širina vrata i prozora [m]
W	širina zgrade [m]
L	dužina zgrade [m]
W_{vv}	širina vrata za vozila [m]
H_{vv}	visina vrata za vozila [m^2]
P_{zo}	površina zida bez otvora [m^2]
P_v	površina vrata [m^2]

P_p	površina prozora [m ²]
P_{pp}	površina potkrovnog prozora [m ²]
P_{puk}	ukupna površina prozora [m ²]
P_{vv}	površina vrata za vozila [m ²]
P_z	površina zida [m ²]
P_k	površina krova [m ²]
ΔP_z	pogreška mjerenja površine zida [m ²]
ΔP_v	pogreška mjerenja površine prozora [m ²]
ΔP_{puk}	pogreška mjerenj ukupne površine prozora [m ²]
ΔP_{vv}	pogreška mjerenja površine vrata za vozila [m ²]
ΔP_k	pogreška mjerenja površine krova [m ²]
$R_{\Delta P_z}$	relativna pogreška mjerenja površine zida [%]
$R_{\Delta P_v}$	relativna pogreška mjerenja površine vrata [%]
$R_{\Delta P_{vv}}$	relativna pogreška mjerenja površine vrata za vozila [%]
$R_{\Delta P_k}$	relativna pogreška mjerenja površine krova [%]
$R_{\Delta P_{puk}}$	relativna pogreška mjerenja ukupne površine prozora [%]

SADRŽAJ

1. UVOD	2
2. DALJINSKA ISTRAŽIVANJA I MOGUĆNOSTI PRIMJENE	2
2. 1. Elektromagnetsko zračenje	2
2. 2. Daljinska istraživanja	7
2. 3. Primjena daljinskih istraživanja	10
3. FOTOGRAMetriJA I STEREOSKOPSKA PARALAKSA	17
4. DEFINIRANJE PROBLEMSKOG ZADATAKA I METODOLOGIJA RJEŠAVANJA	23
4.1 Problemski zadatak	23
4.2. Metodologija Rješavanja	24
5. IZRAČUN DIMENZIJA I KLASIFIKACIJA POVRŠINA OBJEKTA	29
6. STATISTIČKA ANALIZA POGREŠKE I USPOREDBA REZULTATA MJERENJA I STVARNIH VRIJEDNOSTI	37
6. 1. Greške u mjerenju stereoskopskom paralaksom	37
6. 2. Statistička analiza pogreške.....	38
6. 3. Usporedba rezultata mjerenja i stvarnih dimenzija	41
7. ZAKLJUČAK.....	44
LITERATURA.....	45
POPIS SLIKA	46
POPIS TABLICA.....	47
PRILOZI	48
Prilog 1. Parovi fotografija mjerenja visina objekta	48
Prilog 2. Parovi fotografija mjerenja širine objekta.....	52
Prilog 3. Parovi fotografija mjerenja dužina objekta.....	56

1. UVOD

Za mjerenje dimenzija objekata snimljenog iz zraka ključna su dva događaja u povijesti. Razvoj kamera sredinom 19. st. omogućio je lako očuvanje stvarnih odnosa i veličina među objektima na papiru, odnosno fotografiji. Drugi važan događaj je razvoj letenja, prvo balonima na topli zrak, a zatim i zrakoplovima. Prve fotografije iz zraka snimio je Felix Tournachon 1858. g. nad dolinom Bievre kamerom ovješenoj o balon. Nažalost ove fotografije nisu ostale sačuvane do danas. Najstarija očuvana fotografija iz zraka je nastala 1860. g. i prikazuje američki grad Boston. Za nju je zaslužan James Wallace Black.


Snimanjem iz zraka omogućeno je jeftino i lako mapiranje velikih i često nepristupačnih terena. Lansiranjem satelita u zemljinu orbitu omogućeno je praćenje skoro cijele zemaljske kugle u stvarnom vremenu. Određivanje dimenzija iz fotografija naziva se fotogrametrija, prema grčkim riječima za svjetlost i mjerenje. Ako se isti objekt snima iz više kuteva mijenja se i perspektiva. Ta razlika u perspektivi omogućuje mjerenje udaljenosti i veličine među objektima na fotografiji. Upravo fotogrametrijom astronomi i astrofizičari računaju udaljenosti između dalekih zvijezda.

Ovaj rad podijeljen je u dva dijela. Teorijski i praktični dio. Prvi dio daje teorijsku podlogu i sastoji se od kratke teorije elektromagnetskih (EM) valova, dijelova kamere, načina snimanja iz zraka, primjene fotogrametrije u raznim granama industrije. Drugi dio je praktični i sastoji se od definiranja problemskog zadatka, prikaza i analize rezultata. U njemu je pristupljeno hipotetskoj obnovi napuštenog vojnog objekta na kampusu Borongaj. Snimanjem iz zraka dobit će se fotografije čijom će se analizom odrediti površine objekta s ciljem kupovine potrebnog materijala za obnovu.

2. DALJINSKA ISTRAŽIVANJA I MOGUĆNOSTI PRIMJENE

2. 1. Elektromagnetsko zračenje

Sva tijela temperature iznad apsolutne nule emitiraju EM zračenje. Ono nastaje zbog titranja jezgre atoma koja stvara električno polje \vec{E} . Ukoliko se taj električni naboj giba dolazi do stvaranja magnetskog polja \vec{M} . EM zračenje širi se konstantnom brzinom \vec{C} koja iznosi približno $3 \cdot 10^8$ m/s (Slika 1.).




Slika 1. Električno i magnetsko polje EM vala [2]

EM valovi jedinstvena su pojava u prirodi i imaju četiri važna svojstva. Za razliku od ostalih valova koji se šire nekim sredstvom, EM valovi se mogu širiti vakuumom. Drugo svojstvo EM valova je da električno i magnetsko polje u linearno polariziranom EM valu su u fazi. Nadalje smjerovi električnog i magnetnog polja u EM valu su okomiti jedan na drugi i oba su okomita na smjer širenja vala, što ih čini transverzalnim valovima. Brzina EM valova ovisi o električnim i magnetnim svojstvima medija u kojim se šire. Kada se opisuje EM zračenje ono se opisuje sa četiri fizikalne veličine. Valna duljina, λ , je udaljenost od jednog valnog vrha do drugog. Izražava se jedinicama duljine i može imati vrijednost od više desetaka kilometara u radio području pa sve do nekoliko pikometara kod ionizirajućih gama zraka. Druga karakteristična veličina je frekvencija. Ona se mjeri kao broj brjegovu koje prolaze fiksnu točku u nekom vremenu. Kao mjerna jedinica standardno je koriste herci [Hz] koji

označavaju broj titraja u jednoj sekundi. Valna duljina i frekvencija su obrnuto proporcionalne, kako jedna raste, druga pada i obrnuto. Formula glasi:

$$f = \frac{c}{\lambda}. \quad (1)$$

Vrijednosti frekvencija iznose svega nekoliko herca kod ekstremno niskih frekvencija. Frekvencija ionizirajućeg gama zračenje može biti veća i od 10^{19} Hz. Amplituda je treća karakteristična veličina kojom se opisuje EM zračenje i označava visinu brijega, odnosno razinu energije vala. Ovisno o vrsti zračenja amplituda se mjeri u vatima po metru na kvadrat po hercu [$\text{W} \cdot \text{m}^{-2} \cdot \text{Hz}^{-1}$] za radiovalove, ili vatima po metru na kvadrat po nanometru [$\text{W} \cdot \text{m}^{-2} \cdot \text{nm}^{-1}$] za ionizirajuća zračenja. Posljednja karakteristična veličina je faza u kojoj valovi titraju u odnosu jedan na drugoga. Ako u istom trenutku u nekoj nepomičnoj točki dostižu svoj maksimum onda je titranje u fazi, pomak je nula. Ako postoji razlika titranje nije u fazi i ono se izražava u kutnim jedinicama kao što su stupnjevi ili radijani. Fizikalne veličine vala prikazane su na Slici 2.




Slika 2. Karakteristične veličine elektromagnetskog zračenja

Zračenja se u pravilu dijele prema frekvenciji, odnosno valnoj duljini. EM spektar pokriva valne duljine od više tisuća kilometara pa sve do veličine atomske jezgre. Spektar se frekvencijski dijeli u pojaseve kako je prikazano na Slici 3. Ti pojasevi imaju donju i gornju granicu, tako na primjer visokofrekvencijski pojas obuhvaća zračenje u rasponu od 30 MHz do 3 GHz. EM zračenje se izražava u hercima sve do mikrovalova, nakon kojih se radi praktičnosti koriste valne duljine. Prema vrsti zračenja EM spektar se dijeli na:

- Gama zračenje - nastaje raspadom atomske jezgre, velika moć prolaska kroz materijale;
- Rendgensko zračenje - ionizirajuće zračenje, koriste se u medicini;


- Ultraljubičasto zračenje - izaziva kemijske reakcije, štetno po ljudsko zdravlje;
- Vidljivu svjetlost - zračenje koje apsorbira ljudsko oko;
- Infracrveno zračenje - poznato kao toplinsko zračenje dijeli se na daleko, srednje i blisko;
- Mikrovalno zračenje - mikrovalne pećnice, Wifi odašiljači;
- Radiovalove - radio komunikacija, navigacijski uređaji, mobilni uređaji, sateliti.



Slika 3. Podjela elektromagnetskog spektra

Najpoznatiji oblik EM zračenja je vidljiva svjetlost koja je samo mali dio spektra i jedini koji ljudi mogu detektirati golim okom. Taj pojas je uzak i obuhvaća valne duljine od 400 nm do 700 nm. Sunčevo zračenje u ovom pojasu prolazi uglavnom neometano kroz zemljinu atmosferu. Zračenje u svim valnim duljinama vidljivog spektra naziva se bijela svjetlost. Ako se neki objekt obasja bijelom svjetlosti on će, ovisno o svojstvima, određene valne duljine ili reflektirati ili apsorbirati. Senzor kamere ili ljudsko oko primit će samo reflektirano zračenje (Slika 4.). Za objekt će se reći da je žute boje ako apsorbira zračenja svih valnih duljina osim onih od 570 nm do 590 nm. Među valnim duljinama boja ne postoji čvrsta granica, ali uvriježena je podjela:

- Ljubičasta – 380 nm - 450 nm;
- Plava – 450 nm – 495 nm;
- Zelena – 495 nm – 570 nm;
- Žuta – 570 nm – 590 nm;
- Narančasta – 590 nm – 620 nm;
- Crvena – 620 nm – 750 nm.



Slika 4. Reflektirano zračenje u području vidljive svjetlosti [1]

U pojasu vidljive svjetlosti nisu sadržane sve boje koje ljudi mogu razlučiti. Boje poput roze se ne nalaze u spektru već nastaju kombinacijom više valnih duljina. Boje nastale zračenjem na samo jednoj valnoj duljini nazivaju se čiste boje.

Infracrveno zračenje (engl. Infrared ili IR) je zračenje većih valnih duljina od vidljive svjetlosti. Ono obuhvaća EM zračenje valnih duljina od 700 nm do 1 mm. Infracrveno zračenje nastaje kada se molekule rotiraju i vibriraju na temperaturama kakve jesu na zemlji. Otkriveno 1800. g. promatranjem utjecaja zračenja pojasa ispod vidljivog pojasa na termometar. Oko polovice zračenja sunca koje dopiše do zemlje je upravo u infracrvenom području. Zračenje u području vidljive svjetlosti koja se apsorbira u tlo ponovno zrači natrag u atmosferu, tako da je postotak infracrvenog zračenja još i veći. Infracrveno zračenje uvjetno se može nazvati i toplinsko zračenje. Omjer infracrvenog zračenja koje se apsorbira u zemlju i reflektira o zemljinu površinu ima ključan utjecaj na zemljinu klimu. Predmeti na sobnoj temperaturi emitirat će zračenje u rasponu od 8 μm do 25 μm . Područje infracrvenog zračenja dijeli se na nekoliko užih područja ovisno o svojstvima.

Blisko infracrveno područje (engl. Near Infrared ili NIR) je područje valnih duljina od 750 nm do 1,4 μm . Tijela temperature od 1800 °C do 3600 °C zrače u ovom pojasu. Voda jako dobro apsorbira ovo zračenje, a svoju primjenu je našlo u optičkim kabelima. Neke noćne životinje mogu detektirati infracrvena zračenja. Senzori osjetljivi na blisko infracrveno područje koriste se u vojnoj industriji za izviđanje i nadzor noću ili u lošim uvjetima vidljivosti.

Kratkovalno infracrveno područje (engl. Short-wavelength infrared ili SWIR) je područje valnih duljina od 1,4 μm do 3 μm . Ovim pojasem zrače tijela temperatura od 700 °C do 1800 °C. Apsorpcija vode je najveća pri valnoj duljini od 1450 nm. U području valnih duljina od 1530 nm do 1560 nm odvija se većina komunikacije na velike udaljenosti.

Srednjevalno infracrveno područje (engl. Mid-wavelength infrared ili MWIR) je područje od 3 μm do 8 μm . Temperature koje najviše zrače u ovom području su od 90 °C do 690 °C. Ovaj pojas poznat je kao termalni infracrveni pojas. Jedna od primjena ovog zračenja je navođenje projektila i raketa. Pasivno infracrveno navođenje je elektronsko usmjeravanje projektila prema izvoru topline. Toplina ispuha zrakoplova širi EM zračenje valnih duljina od 3 μm do 5 μm koje je jedinstveno u okolišu tako da ga je lako primjetiti i pratiti.

Dugovalno infracrveno područje (engl. Long-wavelength infrared ili LWIR) je područje valnih duljina od 8 μm do 15 μm . Temperature od -80 °C do 90 °C razvijaju ovakvo zračenje, što znači da je gotovo sva tijela zrače upravo u ovom području. Još se naziva i pojas za termalno očitavanje jer pasivni senzori mogu jasno razlučiti objekte čija se temperatura razlikuje od temperature okoline. Pasivni senzori ne zahtijevaju vanjski izvor EM zračenja već detektiraju zračenje samog objekta od interesa.

Daleko infracrveno područje (engl. Far infrared ili FIR) je područje valnih duljina od 15 μm do 1 mm. Zračenje tih valnih duljina postižu tijela temperatura od -270,15 °C do -80 °C. Izvor ovim zračenjima su svemirska tijela i pojave, tako da je se pomoću zračenja u dalekom infracrvenom području mapira svemir.




Slika 5. Bojenje fotografije u infracrvenom području [2]

Fotografije i snimke u ovom području nije moguće vidjeti bez posebnih tehnika analize. Tehnika pridodavanja boje zapisima koji nemaju vidljive boje naziva se lažno bojanje (Slika 5.). Tako se zračenjima u svim nevidljivim djelovima spektra pridodaju boje vidljive svjetlosti kako bi ih se moglo jednostavnije interpretirati.

Budući da su poznate fizikalne zakonitosti rasprostiranja EM valova, zračenja u području vidljive svjetlosti i infracrvenom području moguće je pratiti s lakoćom. Zračenja u tim područjima imaju široku primjenu u granama poput agronomije ili hidrologije. Promatranje interakcije EM zračenja s okolinom čini osnovu daljinskih istraživanja.

2. 2. Daljinska istraživanja

Daljinsko istraživanje u najjednostavnijem smislu se može definirati kao dobivanje informacija o udaljenim objektima. Ključna riječ u ovom slučaju je udaljenost. Bez mogućnosti neke vrste fotografskog zapisa nije moguće dobivanje informacija na udaljenim područjima. Za daljinska istraživanja najviše se koriste kamere. Leća kamere prikuplja reflektirano svjetlo kako bi se formirala slika. Takva slika "pada" na foto-osjetljivu površinu. Film na koji se pohranjuju fotografije je namotan u role i smješten u spremištu za film. Okidač kontrolira ulazak svjetla. Sve dijelove na mjestu drži kućište koje je nepropusno za svjetlo. Na Slici 6. je označen i otvor blende. On služi za kontroliranje inteziteta svjetla, a ne utječe na vidljivo područje ili na veličinu fotografije. Ako postoji potreba na kameru se mogu staviti filteri, npr. filter za snimanje u infracrvenom području.




Slika 6. Dijelovi analogne kamere [1]

Osim analognih koriste se i digitalne kamere. Umjesto foto-osjetljivog filma digitalne kamere koriste matrice koje bilježe EM zračenje. Matrice se sastoje od tisuće čelija zvanih pikseli. Pikseli su premali i ljudsko oko ih ne može razlučiti. U trenutku fotografiranja razina EM zračenja na čelijama se digitalno zabilježava kao numerička vrijednost, često s odvojenim vrijednostima za svaku od nekoliko područja EM spektra. Prednosti digitalnih kamera su da ne trebaju film čime se olakšava transport analiza i čuvanje fotografija. One imaju širi pojas razine svjetlosti koji mogu zabilježiti i mogućnost multispektralnog snimanja.


Svaka fotografija nosi određenu količinu informacija, bilo to o boji, veličini ili međusobnom odnosu više objekata na fotografiji. Ljudi posjeduju veliku količinu interpretativnog znanja i zbog toga nije teško protumačiti čak i vizualno složene slike. Uzmemo li u obzir fotografije snimane iz zraka dobivaju se informacije o obliku zemlje. U tom slučaju više nisu dovoljna samo urođena znanja, jer interpretatoru bez iskustva će biti teško razlikovati jarak od brežuljka. Tada su potrebna su dodatna znanja o tumačenju topografskih elemenata. Tako da na količinu potrebnog znanja za tumačenje utječu čimbenici kao što su nepoznati omjeri, neobične perspektive i nejasna rezolucija fotografije. U slučaju hiperspektralnog snimanja bitno je znati kakva je spektralna slika objekta u uskim pojasevima EM zračenja.

Daljinska istraživanja dijele se na tri osnovna oblika ovisno o valnim duljinama koje senzori primaju. Kod prvog tipa daljinskih istraživanja bilježi se odraz sunčeve energije (Slika 7.). Sunčevo EM zračenje prolazi kroz atmosferu bez većih promjena i stiže na zemlju. Vidljivi dio spektra valnih duljina od 400 nm do 700 nm se reflektira u svim smjerovima. Objektiv kamere potom prima takvo odbijeno EM zračenje i pohranjuje ga digitalno. Ovaj oblik daljinskog istraživanja naziva se pasivni zbog toga što koristi energiju drugog tijela, u ovom slučaju sunca. Osim u vidljivom djelu spektra koristi se i u bliskom infracrvenom području. Ključne varijable za uspješno izvođenje snimanja su jasnoća atmosfere, spektralna svojstva objekta, kut i intenzitet sunčevih zraka te izbor filtera.



Slika 7. Senzor prima sunčevo reflektirano zračenje [1]

Kod drugog tip daljinskih istraživanja kamera bilježi energiju koju tijelo emitira (Slika 8.). Emitirana energija najjača je u dalekom infracrvenom području EM pojasa. EM zračenje sunca dolazi do zemlje koja upija kratkovalna zračenja. Tijelo se grije i potom zrači tu istu energiju na većim valnim duljinama. Emitirano zračenje s površine zemlje otkriva informacije o toplinskim svojstvima materijala koje je lako tumačiti. Voda, vegetacija, površinski materijali i umjetni objekti zrače različitim valnim duljinama u dalekom infracrvenom području. Ostali izvori zračenja mogu biti geotermalni izvori, požari ili termoelektrane. Ova vrsta daljinskih istraživanja također je pasivna jer je izvor zračenja sam objekt koji se fotografira. Ova vrsta daljinskog istraživanja zahtjeva posebne senzore namijenjene snimanju dalekog infracrvenog područja. Osim opreme potrebno je i znanje tumačenja takvih snimki.



Slika 8. Senzor prima infracrveno (termalno) zračenje od zemlje [1]

Treći tip daljinskih istraživanja je aktivni. Za razliku od pasivnih oblika daljinskih promatranja ovaj ima vlastiti izvor energije. Ovakav tip istraživanja je neovisan o sunčevom i zemaljskom zračenju kao što je prikazano na Slici 9. Aktivni senzor emitira vlastito zračenje na područje od interesa nakon čega prima odraz tog istog zračenja. Aktivni senzori su radari i lidari. Radar odašilje uzak val EM zračenja koji se potom reflektira od objekta od interesa i dolazi natrag do radara. Budući da primaju energiju koju sami odašilju ovakvi uređaji se mogu koristiti noću i u lošim meteorološkim uvjetima.




Slika 9. Zračenje napušta zrakoplov, odbija se i vraća natrag prema senzoru [1]

Nakon što je senzor primio EM podražaj on ga pohranjuje u elektroničkom obliku. Taj elektronički zapis se šalje u stanicu u kojoj će se taj zapis analizirati. Od zapisa nastaje slika koju je potom moguće analizirati kako bi se dobile korisne informacije. Postoji više vrsta analiza, vizualna, digitalna ili elektronička. I na kraju ostaje samo iskoristiti dobivene informacije za bolje razumijevanje područja ili rješavanje određenog problema.

2. 3. Primjena daljinskih istraživanja

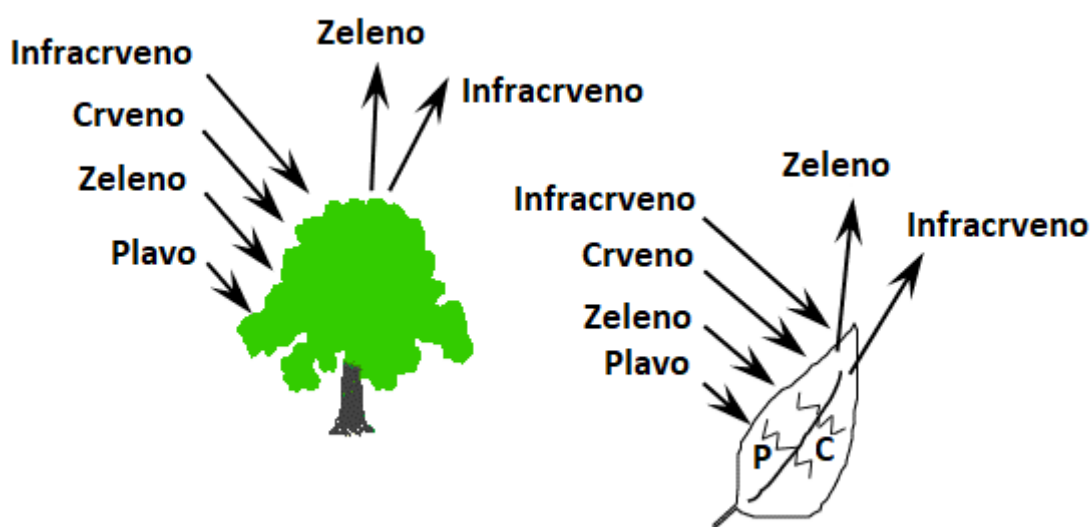
Područje primjene daljinskih istraživanja je široko i rasprostranjeno. Gotovo da nema područja gdje se ne koriste daljinska istraživanja. U ovom poglavlju navedena su samo neka područja i specifične primjene.

Agrokultura ima veliku ulogu u ekonomiji gotovo svih zemalja, stoga je razumljiva čežnja da se procesi obrade tla optimiziraju i time osigura maksimalan urod. Daljinska istraživanja u agrokulturi prvenstveno koriste nacionalne i multinacionalne poljoprivredne agencije kako bi dobile informacije ne samo o vrsti i količini usjeva nego i načinu obrade tla. Tako dobivene informacije služe za predviđanje doprinosa, efektivnosti uzgojnih sredstava, optimiziranje rotacije određenih kultura i mapiranje plodnosti tla (Slika 10.). U slučaju pada prinosa tla daljinskim istraživanjima je moguće utvrditi čimbenike koji utječu na stres kod usjeva. Stres povezan s vlagom, insektima, gljivicama i korovom mora se otkriti dovoljno rano da bi se omogućilo pravovremeno djelovanje. U slučaju nepogoda kao što su suša ili oluja dobivaju se podatci o raširenosti i razini oštećenja usjeva, što je od velike važnosti osiguravajućim kućama. Svaka poljoprivredna kultura ima specifičan spektralni odziv, u slučaju bolesti njen spektralni odziv se mijenja. Procjena zdravlja usjeva i rano otkrivanje bolesti od ključne su važnosti u osiguravanju velikih prihoda. Usjevi uglavnom ne rastu jednako preko cijelog polja. Lokalne razlike u plodnosti mogu biti rezultat nedostataka tla ili hranjivih tvari. Ako poljoprivrednik ima informaciju o problematičnim područjima unutar polja on može primijeniti ispravnu količinu gnojiva ili pesticida. Koristeći ovaj pristup poljoprivrednik ne samo da povećava urod, već smanjuje troškove i utjecaj na okoliš.




Slika 10. Klasifikacija usjeva, sećerna trska (S), pšenica (W), kukuruz (C) i neobrađena zemlja (F) [1]

Zdrava vegetacija sadrži velike razine klorofila, tvari koja vegetaciji daje zelenu boju. Klorofil upija zračenja u plavim i crvenim područjima što znači da je refleksivnost tih pojasa jako niska. Nasuprot tome refleksija u zelenom i bliskom infracrvenom pojasu je visoka (Slika 11.). Oštećeni usjevi imaju smanjene razine klorofila što rezultira manjom refleksijom u zelenom pojasu. Oštećenja također smanjuju i refleksiju u bliskom infracrvenom području. Ispitivanja omjera refleksije u tim područjima izvršna je mjera vegetacijskog zdravlja.



Slika 11. Refleksivnost dirveća i lista [2]

Šume su vrlo važan resurs kojeg je danas sve manje zbog stalnog povećanja potrebe za drvom. Koristeći samo ugljikov dioksid, vodu i sunčevu energiju u stanju su proizvesti velike količine biomase, prvenstveno drva i lišća. One i čiste zrak ne samo koristeći ugljikov dioksid za proizvodnju kisika nego i zadržavajući prašinu. Također šuma je važan faktor u procesu kruženja vode u prirodi. Drvo se koristi kao građevinski materijal, kao gorivo. Od njega se izrađuju predmeti od čačkalice pa do skupocjenih glazbala i umjetnina. Ipak najviše drva, koristi se u industriji papira. Sve više napora ulaže se u očuvanje šuma, smanjenje ilegalne sječe te održivo gospodarenje šumama. Jedan od alata za lakše gospodarenje šumama su upravo daljinska istraživanja. Ona se koriste za planiranje održivog razvoja, za praćenje biološke raznovrsnosti i kontroliranje krčenja šume. Osim toga prate se i površinske erozije uzrokovane manjkom šumskog pokrova kao i promjena staništa šumskih životinja.




Slika 12. Različite razine reflektivnosti u bliskom infracrvenom području za travu, drveća širokih listova i igličastih drveća [2]

Prakse slične onima u agrokulturi uključuju praćenje bolesti drveća i utjecaj nepogoda kao što su oluje ili požari na šumski pokrov. Daljinska istraživanja, odnosno satelitske snimke, najbolje daju informaciju o velikim i nepreglednim površinama kao što su prašume. Dovoljno učestalim prikupljanjima informacija moguće je pratiti procese sječenja i njihov utjecaj na šumu. Fotografijama iz zraka moguće je lako uočiti ilegalne radnje sječe šuma koje bi u suprotnom bilo jako teško otkriti. Ipak daljinska istraživanja najviše se koriste za klasifikaciju šuma. Različite vrste drveća imaju različit spektralni odziv tako da se sa relativnom lakoćom može odrediti zastupljenost određene vrste na određenom području (Slika 12.). Hiperspektralni podaci nude jedinstven pregled šumskog pokrova koji je moguće dobiti samo daljinskim istraživanjima. Važno je napomenuti da je daljinska istraživanja


lakše primjeniti na šumama u umjerenim klimama. U vlažnim tropskim područjima, šume i prašume je teško analizirati radi velike količine vlage i često oblačnog vremena. U tom slučaju pouzdanost prikupljanja podataka je važnija nego visoka razlučivost. Rješenje nude aktivni senzori, odnosno radari.

Geologija je znanost koja se bavi proučavanjem strukture zemlje i podzemlja kako bi se razumjeli procesi koji stvaraju i mijenjaju zemljinu koru. U praksi uključuje istraživanja minerala i ugljikovodika. Geologija je izravno uključena u dobivanje energenata kao što su nafta i plin i građevinskih materijala kao pijesak i šljunak. Iz rudnika dobivaju se plemeniti metali i dragulji za nakit, dijamanti za bušilice te bakar i cink široke namjene. Geologija se bavi i istraživanjem potencijalnih opasnosti kao što su potresi, klizišta ili vulkanske aktivnosti. Daljinska istraživanja u geologiji se primjenjuju kako bi se dobile informacije o strukturi površine. Za razliku od agrokulture i šumarstva, u geologiji je potrebno koristiti i druge komplementarne geološke uređaje. Korištenjem uređaja u kombinaciji moguće je dobivanje multispektralnih podataka o kompoziciji stijena na temelju spektralne refleksije. Također moguće je i otkrivanje radioaktivnih materijala zbog njihovog zračenja. Na primjer, zrakoplov se opremi spektrometrom osjetljivim u gama pojasu i time je moguće pronaći nalazišta radioaktivnih materijala kao što su kirij, torij i uran. Ta samostalna očitavanja je potrebno kolocirati s kartom terena ili očitanjima radara, kako bi se dobila točna lokacija. Radar se koristi u slučaju guste vegetacije jer je dovoljno osjetljiv i može prepoznati točke reflektirane o biljke. Uklanjanjem takvih točaka ostaje vjeran prikaz terena ispod biljnog pokrova. Fotoklinometrija je praksa određivanja kosine neke površine u odnosu na izvor svjetla. Mjereći razliku u razini svjetlosti na različitim djelovima planine moguće je izračunati nagibe matematičkih ploha i tako napraviti model planine (Slika 13.). Osim izravne upotrebe, daljinska istraživanja daju i logističku podršku, kao na primjer planiranje rute za pristup udaljenoj lokaciji od interesa.



Slika 13. Fotoklinometrija [1]

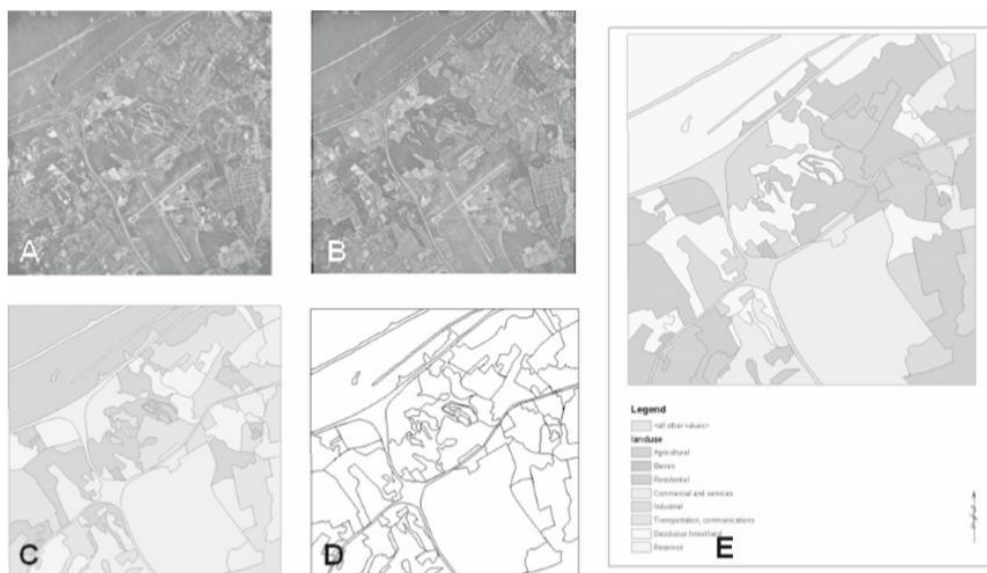
Hidrologija je znanost koja se bavi proučavanjem svih tipova voda, od mora i oceana, preko rijeka i potoka do ledenjaka i snježnih vrhova. Poplave u prirodi su normalna pojava izazvane prekomjernim kišama, poremećajima prirodnih i umjetnih brana ili pak topljenjem leda i snijega. Poznato je da poplave mogu izazvati velike materijalne štete, stoga je potrebno pravovremeno reagirati da ta šteta bude što manja. Daljinska istraživanja u hidrologiji koriste se za praćenje položaja i dinamike hidrologijskih fenomena, koje često nije moguće dobiti istraživanjima na terenu. U slučaju poplava lako je dobiti podatke o zahvaćenim područjima i razini nanesene štete. Uvjeti poplave traju relativno kratko vrijeme i za takve potrebe mogu se koristiti senzori osjetljivi na vidljivu svjetlost na zrakoplovu. No, poplave vrlo često sa sobom donose loše vrijeme i veliku naoblaku čime eliminiraju mogućnost korištenja takvih senzora. U tim slučajevima koristi se aktivni radar koji omogućuje kontinuirano praćenje u stvarnom vremenu čak i u lošim vremenskim uvjetima. Tako dobivene informacije se integriraju sa kartama područja prije same poplave. Na takve karte se potom dodavaju podatci geografskog informacijskog sustava (GIS) kako bi se dobile informacije o katastarskim jedinicama i prometnicama pod vodom.



Slika 14. Praćenje erozije obale uslijed morskog djelovanja [1]

Ostale mogućnosti korištenja daljinskih istraživanja u hidrologiji uključuju meteorološka mjerenja, određivanje vlage tla, praćenje gibanja i stanja ledenjaka, erozija obale (Slika 14.), kontroliranje zagađenja u morima i oceanima, planiranja promjena korita rijeka i potoka.

Zemljišta se klasificiraju prema pokrovu. Tako se razlikuju golo tlo, vegetacija, urbana infrastruktura, vodene površine i slično. Identifikacija i mapiranje kopnenog pokrova bitni su za studije praćenja, upravljanja i planiranja budućih aktivnosti. Prema pokrovima nastaju tematske karte područja za određene aktivnosti. Takve aktivnosti vezuju se za upotrebu ili korištenje tla. Upotreba zemljišta odnosi se na svrhu koju zemlja služi. Razlikuju se poljoprivredna područja, rekreativni prostori, staništa divljih životinja i slično. Tematske ili topografske karte bitne su za optimalno upravljanje zemljištem pogotovo ako su digitalno integrirane u GIS. Mapiranje zemljišta i praćenje promjena daje jedinstvenu informaciju kako se razvija društvo. Na primjer daljinskim istraživanjima je vrlo lako utvrditi kako se razvija i širi neka urbana sredina. Mapiranje predstavlja sastavni dio procesa upravljanja zemljišnim resursima. Prostorno se prikazuje velika količina informacija kao što su prirodne pojave, umjetno stvorena infrastruktura, urbana područja i administrativne granice. Mapiranje prostora može vršiti svatko tko je zainteresiran za iskorištavanje određenog područja. Takve karte koristit će se kao polazna točka za buduće praćenje i upravljanje zemljištem. Metodama daljinskih istraživanja klasificiraju se velike površine na vrlo praktičan i ekonomičan način. Na Slici 15. prikazani su koraci tijekom mapiranja. Na fotografiji iz zraka (A) ocrtavaju se granice različitih područja (B). Ta područja dijele se u klase (C). Klase se potom označavaju (D). Dodavanjem ostalih informacija kao što su legenda, mjerilo ili oznaka sjevera mapa je gotova (E).




Slika 15. Koraci u procesu mapiranja [1]

Prednosti korištenja daljinskih istraživanja naspram drugih metoda mapiranja su:

- Stereoskopsko snimanje;
- Lakoća ponavljanja snimanja u slučaju vremenski osjetljivih zadataka;
- Brzina analize i dostave podataka;
- Pokrivanje širokog područja;
- Potrebno je manje ljudi i vremena;
- Pohrana u digitalnom obliku koja olakšava ažuriranje i integraciju s GIS-om.


3. FOTOGRAMetriJA I STEREOSKOPSKA PARALAKSA

U daljinskim istraživanjima najviše se koriste fotografije iz zraka, jer sadrže najveću količinu informacija. Ovisno o usmjerenju kamere u odnosu na površinu snimanja razlikuju se tri vrste zračnih fotografija (Slika 16.). Fotografije vertikalne perspektive se dobivaju usmjerenjem kamere okomito na površinu snimanja, odnosno zemlju. Ako se kamere usmjere prema obzoru (na bilo koju stranu) dobivaju se fotografije kose perspektive. Takve fotografije ovisno o kutu usmjerenja možemo dijeliti na fotografije blago kose perspektive i fotografije izraženo kose perspektive. Fotografije izraženo kose perspektive u pravilu prikazuju horizont i najintuitivnije su od tri navedene perspektive. U slučaju fotografiranja s iste visine one prikazuju i najveće područje. Unatoč tome rijetko se koriste zbog velike promjene mjerila udaljenijih objekata. Iako neintuitivne i teško čitljive neutreniranom oku, najviše se koriste zračne fotografije vertikalne perspektive. Glavne prednosti vertikalne perspektive su predvidljiva geometrijska svojstva koja su ključna za rješavanje praktičnih problema.




Slika 16. Perspektive fotografija iz zraka

Zrakoplov koji obavlja mapiranje određenog područja letjeti će u paralelnim linijama i fotografirati u nizu. Frekvencija fotografiranja ovisi o zadatku. Ako će fotografije biti korištene za izračunavanje udaljenosti frekvencija fotografiranja će biti veća. U slučaju izviđanja terena ta frekvencija je manja. Kod većih frekvencija fotografiranja dolazi do preklapanja fotografija. To preklapanje izražava se u postotcima fotografiranog terena koji će biti vidljiv na dvije fotografije. Ako je preklapanje 50 % i veće na svakoj fotografiji moguće je vidjeti centar prošle ali, i sljedeće fotografije (Slika 17.). Ovakva vrsta fotografskog pokrivanja naziva se stereo triplet.




Slika 17. Prekapanje fotografija snimljenih iz zraka

Znanost mjerenja i dobivanja dimenzija iz fotografija naziva se fotogrametrija. To je znanost izrade preciznih mjerenja iz fotografija. Fotogrametrija primjenjuje principe optike i znanja o radu kamera kako bi se odredile dimenzije i položaji objekata sa fotografije. Kako bi mjerenja bila što točnija potrebno je dobro poznavanje kamere, kao i uvjeta u kojim je korištena za vrijeme dobivanja fotografije. Fotogrametrija se može primijeniti na bilo kojoj fotografiji ako je moguće rekonstruirati optičku geometriju fotografije. U slučaju vertikalnih fotografija zemlje za optičku geometriju potrebno je znati visinu letjelice na kojoj je kamera snimila područje. Fotogrametrija se primjenjuje na fotografijama iz zraka kako bi se dobile topografske visine tijekom mapiranja (Slika 18.).



Slika 18. Fotografiranje iz zraka tijekom topografskog mapiranja

Ako se isto područje fotografira iz različitih perspektiva, odnosno sa više različita mjesta promatranja, primjetna je promjenu u položaju i obliku objekata na fotografijama. Isto je moguće primijetiti ukoliko žmirimo na jedno oko. Na Slici 19. je prikazana razlika u perspektivi lijevog i desnog oka. To je razumljivo budući da su zjenice udaljene jedna od druge. Razlika u perspektivi naziva se paralaksa. Količina paralakse se smanjuje s povećanjem udaljenosti od promatrača, odnosno objektiva kamere. Paralaksa uvelike pomaže percepciji dubine kod ljudi i životinja.



Slika 19. Razlika u percepciji lijevog i desnog oka

Paralaksom je moguće riješiti puno praktičnih problema. Astronomi i astrofizičari koriste paralaksu za izračunavanje udaljenosti između udaljenih planeta i zvijezda. Ovisno o potrebi koriste dinamičku, zvjezdanu, mjesečevu i sunčevu paralaksu. Za računanje visine objekata u daljinskom istraživanju koristi se stereoskopska paralaksa. Paralaksa će biti izraženija na višim objektima budući da su bliži kameri. Za izračunavanje visine objekta na zemlji potrebno je znati visinu leta zrakoplova. Na Slici 20. su prikazane dvije uzastopne fotografije snimljene iz zraka vertikalnom perspektivom. Objekt od interesa označen je crvenom bojom. Primjenom stereoskopske paralakse moguće je izračunati visinu objekta na sljedeći način:

$$h = \frac{H \cdot dp}{P + dp}, \quad (2)$$

$$dp = a - b, \quad (3)$$

$$P = x - y. \quad (4)$$

Gdje vrijedi:

h = visina objekta;

H = visina leta zrakoplova;


a, y = udaljenost baza objekta;

b = udaljenost vrhova objekta;

x = udaljenost centara dvaju fotografija;


dp = diferencijska paralaksa;

P = razlika udaljenosti centara fotografija i udaljenosti baza objekta.



Slika 20. Stereoskopska paralaksa

Primjer primjene stereoskopske paralakse na zastavici zagrebačke XV. gimnazije (Slika 21.). Jedina informacija potrebna za primjenu paralakse jest visina snimanja. U ovom slučaju fotografije su snimljene sa visine od 1 m. Ako se u obzir uzme postolje zastavice od dva centimetra dobiva se visina snimanja od 98 cm.



Slika 21. Mjerenje visine zastavice stereoskopskom paralaksom

Fotografije su ispisane na papiru A4 formata i izmjerene su sljedeće udaljenosti:

visina snimanja (H) = 98 cm;

udaljenosti baza objekta (a, y) = 15,8 cm;

udaljenosti vrhova objekta (b) = 9,7 cm.

Uvrštavanjem izmjerenih udaljenosti u prethodno navedene formule (1, 2, 3) dobiva se:

$$dp = a - b = 15.8 - 9.7 = 6.1 \text{ cm};$$

$$P = x - y = 29.8 - 15.8 = 14 \text{ cm};$$

$$h = \frac{H \cdot dp}{P + dp} = \frac{98 \cdot 6,1}{14 + 6,1} = \frac{597,8}{20,1} = 29,74 \text{ cm}.$$

Stvarna visina zastavice je 30 cm što znači da je pogreška 2,6 mm.

4. DEFINIRANJE PROBLEMSKOG ZADATAKA I METODOLOGIJA RJEŠAVANJA

4.1 Problemški zadatak

Napušteni vojni objekt (Slika 22.) na kampusu Borongaj je potrebno renovirati. Pretpostavlja se da je put do objekta zakrčen i da je mjerenja potrebno osigurati daljinskim istraživanjima. Daljinskim istraživanjima je potrebno izračunati sljedeće:

- Dimenzije objekta;
- Površinu krova koji će se mijenjati;
- Površinu vanjskih zidova koji će se bojati;
- Površina otvora (vrata, prozori i vrata za vozila) koje će se mijenjati.



Slika 22. Napušteni vojni objekt na kampusu Borongaj; Izvor: Google Earth, kolovoz 2018

Ograničenje: Radi pojednostavljanja zadatka pretpostavlja se da su nasuprotne stranice objekta jednake.

4.2. Metodologija Rješavanja

Površine objekta će se podjeliti na dvije skupine, zid i otvore. Otvori uključuju sva vrata, prozore i ulaza za vozila. Aproksimacije površina prednje i bočne strane objekta vidljive su na Slici 23. i Slici 24.



Slika 23. Aproksimacija površina prednje strane objekta



Slika 24. Aproksimacija površina bočne strane objekta

Kako bi se došlo do potrebnih informacija iz snimanja, potrebno je izračunati više veličina (Slika 25.).

Vertikalnim mjerenjem potrebno je izračunati:

- Visinu po sredini zgrade - H_c ;
- Visinu ruba - H_r ;
- Visinu vrata - H_v ;
- Visinu prozora - H_p .


Bočnim mjerenjem računati će se:

- Širina zgrade - W .

Frontalnim mjerenjem računati će se:

- Dužina zgrade - L ;
- Širina vrata za vozila - W_{vv} .

Na Slici 25. su označene su i neke veličine koje se neće računati paralaksom a ključne su za rješavanje zadatka. Te veličine su širina vrata, širina prozora i širina i visina potkrovnog prozora. Budući da se red od dvadeset jednako širokih prozora proteže cijelom širinom zgrade, jednostavnim djeljenjem širine zgrade dobit će se širina jednog prozora. Nadalje, širina prozora jednaka je širini vrata pa se ni ona neće računati paralaksom. Zajedno su označene kraticom W_{vp} . Vrata i 5 prozora na boku objekta veličinom su jednaka onima na prednjoj strani zgrade tako da se ni oni neće računati posebno. Treća veličina koja se neće računati paralaksom jest širina potkrovnog prozora pošto je ona jednaka širini dvanaest prozora. Testnim snimanjem iz zraka utvrđeno je da krov koji ide preko ruba zgrade zaklanja pogled na potkrovni prozor. Iz toga razloga nije moguće paralaksom dobiti njegovu visinu, na Slici 25. označenu s H_{pp} . Stoga će se visina potkrovnog prozora aproksimirati kao jednu petinu visine zgrade H_p .



Slika 25. Ključne veličine za rješavanje problemskog zadatka

Izvest će se četiri nezavisna mjerenja. Jedno mjerenje označava 6 fotografija, dvije za svaku dimenziju. Dvije fotografije za istu dimenziju nazivaju se par. Parovi fotografija razlikovat će se za svako od mjerenja. Mjerenja se tako dijele po udaljenosti od baze objekta duž smjera snimanja i po bočnoj udaljenosti od objekta. Po uzdužnoj udaljenosti parovi će se dijeliti na bliže ili udaljene, a po bočnoj udaljenosti na vanjske i unutarnje. Slika 26., Slika 27. i Slika 28. prikazuju parove snimanja za sve tri dimenzije. Parovi fotografija označene su bojama. Crvenom bojom označeni su bliži unutarnji parovi, žutom bliži vanjski. plavom bojom označeni su udaljeni unutarnji parovi, a zelenom udaljeni vanjski. Za potrebe rješavanja zadatka ukupno će biti snimljene 24 fotografije koji se mogu vidjeti u prilogima na kraju rada.



Slika 26. Planirani parovi prednjeg snimanja



Slika 27. Planirani parovi bočnog snimanja



Slika 28. Planirani parovi vertikalnog snimanja

U sljedećem poglavlju mjerenja će biti označena rednim brojevima na sljedeći način:

- 1. mjerenje, bliži unutarnji parovi (označeni crvenom bojom);
- 2. mjerenje, bliži vanjski parovi (označeni žutom bojom);
- 3. mjerenje, udaljeni unutarnji parovi (označeni plavom bojom);
- 4. mjerenje, udaljeni vanjski parovi (označeni zelenom bojom).

Sva snimanja će biti obavljena snimanjem iz zraka koristeći bespilotnu letjelicu u vlasništvu Fakulteta prometnih znanosti (Slika 29.). Letjelica je ručno sastavljena u sklopu praktične nastave na kolegiju Zrakoplovno izviđanje i nadzor. Radi se o heksakopteru veličine 75 x 75x 35 cm sa 6 motora tipa Outrunner snage 480 W. Pogonjen je bateriom od 5000 mAh i teži 4,420 kg. Kamera će biti ovješena o stabilizacijski sustav da se osigura neovisnost nagiba kamere o nagibu letjelice.



Slika 29. Bespilotna letjelica ustupljen od strane fakulteta prometnih znanosti


Visina kod vertikalnog snimanja i udaljenost kod horizontalnog snimanja biti fiksne jer o njima ovisi točnost mjerenja. Bočne udaljenosti ovise uvelike o okolnoj prirodi i neće biti naglašene jer nisu bitne za račun. To ne znači da na njih ne treba obratiti pozornost. Snimanje će biti obavljeno GoPro Hero 6 kamerom. Polje vidljivosti (engl. Field of view) kamere je 122,6° horizontalno i 94,4° vertikalno. To su ograničenja bočne udaljenosti kojih se treba pridržavati.

Visina leta bespilotne letjelice će se računati barometarskim sustavom određivanja visine u samoj letjelici. Bespilotna letjelica kao i kamera ima mogućnost pozicioniranja preko GPS-a. Dobivene pozicije će biti korištene kako bi se dobila udaljenost duž smjera snimanja.

Po završavanju snimanja setreoskopskom paralaksom će se računati vrijednosti prethodno navedenih varijabli.


5. IZRAČUN DIMENZIJA I KLASIFIKACIJA POVRŠINA OBJEKTA

Obzirom na karakteristike kamere i dimenzije objekta procijenjene su visine snimanja 10 m i 15 m. Bepilotna letjelica korištena za snimanje pohranjuje sve podatke o letu. Po završetku leta tim podacima se pristupilo koristeći program *Mission Planner*. Bepilotna letjelica je svojim barometarskim visinomjerom zabilježila podatke o visini prikazane na Slici 30. Odstupanja u mjerenju visine su bila očekivana i one iznose 11,5 m i 15,5 m. Na Slici 30. je vidljivo da je bepilotna letjelica započela let s visine po tlaku od 1 m. Oduzme li se ta polazišna visina dobivaju se stvarne visine leta od 10,5 m i 14,5 m. S tim visinama leta računati će se potrebne dimenzije objekta.



Slika 30. Računanje visine leta bepilotne letjelice u programu Mission Planner

Slijedi postupak dobivanja visine objekta iz prvog snimanja sa 10,5 m. Visina je uvrštena u formule (1, 2 i 3). Postupak mjerenja prikazan je na Slici 31.



Slika 31. Mjerenje visine zgrade primjenom stereoskopske paralakse na fotografijama dobivenim snimanjem iz zraka

Računski postupak glasi:

$$h = \frac{H \cdot dp}{P + dp},$$

$$dp = 231 - 108 = 123 \text{ mm};$$

$$P = 297 - 231 = 66 \text{ mm};$$

$$h = \frac{10500 \cdot 123}{66 + 123} = 6833 \text{ mm}.$$

Stereoskopskom paralaksom dobivena je visina zgrade od 6,83 m.

Što je za vertikalna mjerenja visina od tla, za horizontalna mjerenja to je udaljenost od nasuprotnog zida objekta. Udaljenosti su mjerene globalnim položajnim sustavom. Za potrebnu širinu zgrade fotografije su snimljene na bočnoj udaljenosti od suprotnog kraja objekta 38 m za bliže parove i 53,5 m za dalje. Kako bi se dobila dužina zgrade fotografije su snimljene na prednjoj udaljenosti od kraja zgrade 46 m za bliže parove i 58 m za dalje. Putanje snimanja horizontalnih letova i udaljenosti prikazane su na Slici 32.



Slika 32. Udaljenosti pravaca snimanja objekta za dobivanje horizontalnih dimanzija

Slijedi primjer računanja dužine zgrade s udaljenosti od 46 m. Karakteristične veličine i izmjerene vrijednosti prikazane su na Slici 33., a postupak glasi:

$$h = \frac{H \cdot dp}{P + dp},$$

$$dp = 228 - 73 = 155 \text{ mm};$$

$$P = 297 - 228 = 69 \text{ mm};$$

$$h = \frac{46000 \cdot 155}{69 + 155} = 31830 \text{ mm}.$$



Slika 33. Mjerenje duljine zgrade primjenom stereoskopske paralakse na fotografijama dobivenim horizontalnim snimanjem

Paralaksom dobivena je duljina zgrade od 31,83 m.

Prema planu rješavanja problemskog zadatka definiranog u prošlom poglavlju postupak stereoskopske paralakse je ponovljen za četiri vertikalne vrijednosti, dvije uzdužne i jednu širinsku. Zatim su svi proračuni ponovljeni za svako od četiri mjerenja. Mjerenja će biti označena kraticama S , prvo mjerenje je S_1 , drugo S_2 itd. Vrijednosti definirane u prošlom poglavlju dobivene su stereoskopskom paralaksom i prikazane u Tablici 1.

Tablica 1. Vrijednosti dobivene stereoskopskom paralaksom

	S_1	S_2	S_3	S_4
H_c [m]	6,83	6,89	6,61	6,45
H_r [m]	5,28	5,16	5,03	5,12
H_v [m]	2,25	2,42	2,43	2,23
H_p [cm]	75,2	84,34	86,17	63,87
W [m]	19,84	19,47	20,17	17,26
L [m]	32,57	31,83	30,29	27,33
W_{vv} [m]	3,73	4,17	3,91	3,97

Navedenih sedam veličina nije dovoljno za rješavanje problemskog zadatka. Uz pomoć sedam veličina navedenih u Tablici 1. moguće je izračunati sve veličine koje su potrebne za rješavanje problemskog zadatka. Prva od tih vrijednosti je širina prozora. Red prozora pruža se duž cijele prednje strane zgrade. Budući da je u tom nizu dvadeset prozora dijeljenjem širine objekta W s 20 dobiti će se širina jednog prozora. Nadalje širina vrata jednaka je širini prozora. Obije širine bit će označene istom kraticom W_{vp} . Širina potkrovnog prozora jednaka je širini dvanaest prozora tako da će se ona računati množenjem širine prozora. Visinu potkrovnog prozora H_{pp} nije bilo moguće izračunati paralaksom zbog krova zgrade. U planiranju i pripremi mjerenja definirano je da će se aproksimirati kao 20 % ukupne visine zgrade. U slučaju vrata za vozila njihova je širina dobivena paralaksom a njihova visina jednaka je visini zgrade na rubu. Dimenzije vrata i prozora računati će se na pročelju objekta. Vrata i prozori na boku objekta jednake su visine i širine kao oni na pročelju stoga njihove dimenzije nije potrebno posebno računati. Navedene vrijednosti izračunate su za svako mjerenje i prikazane su u Tablici 2. skupa s osnovnih sedam veličina dobivenih paralaksom.

Tablica 2. Veličine proračunate iz veličina dobivenih stereoskopskom paralaksom

	S_1	S_2	S_3	S_4
W [m]	19,84	19,47	20,17	17,26
L [m]	32,57	31,83	30,29	27,33
H_c [m]	6,83	6,89	6,61	6,45
H_r [m]	5,28	5,16	5,03	5,12
W_{vp} [cm]	99,2	97,35	100,85	86,3
H_v [m]	2,25	2,42	2,43	2,23
H_p [cm]	75,2	84,34	86,17	63,87
W_{pp} [m]	11,9	10,08	12,10	10,35
H_{pp} [m]	1,36	1,37	1,32	1,29
W_{vv} [m]	3,73	4,17	3,91	3,97
H_{vv} [m]	5,28	5,16	5,03	5,12

Za potrebe obnavljanja objekta površine su podijeljene u 5 skupina ovisno o materijalu kojeg treba nabaviti. Od ukupne površine zida zgrade oduzimati će se ostale površine kako bi se dobila površina zida kojeg treba obnoviti. Površina zida bez otvora P_{zo} jednaka je površinama bočnih zidova, koja je visina po rubu zgrade pomnožena s duljinom zgrade. Tome treba dodati širinu zgrade pomnoženu s visinom po rubu i širinu zgrade pomnoženu s visinom po centru. Formula za izračun površine zidova bez otvora tako glasi:

$$P_{zo} = 2 \cdot H_r \cdot L + W \cdot H_r + W \cdot H_c. \quad (5)$$

Prva površina koja će se oduzimati od površine zida bez otvora je površina vrata P_v . Za obnovu objekta predviđena su drvena vrata i na zgradi ih je ukupno 16. Izmjerene visine i širine vrata će se uvrstiti u formulu:

$$P_v = 16 \cdot W_{vp} \cdot H_v. \quad (6)$$

Prozori i potkrovnj prozori su od stakla. Zbog materijala klasificirani su u istu kategoriju. Površina prozora P_p i površina potkrovnjih prozora P_{pp} zajedno čine ukupnu površinu prozora P_{puk} . Na zgradi se nalaze 76 prozora i 2 potkrovnja prozora. Njihove površine računat će se formulom:

$$P_{puk} = 76 \cdot W_{vp} \cdot H_p + 2 \cdot W_{pp} \cdot H_{pp}. \quad (7)$$

Posljednja površina je površina vrata za vozila P_{vv} čija je obije dimenzije su mjerenje paralaksom. U formulu 7. uvrštava se širina vrata za vozila W_{vv} i visina vrata za vozila H_{vv} koja je jednaka visini po rubu zgrade H_r . Na zgradi je ukupno 6 takvih vrata i one će se raditi od lima. Formula glasi:

$$P_{vv} = 6 \cdot W_{vv} \cdot H_r. \quad (8)$$

Površina zida P_z koja će se bojati je stoga površina zida bez otvora P_{zo} od koje se oduzimaju površine vrata P_v prozora P_p i vrata za vozila P_{vv} . Formula za izračun površine zida glasi:

$$P_z = P_{zo} - P_v - P_{puk} - P_{vv}. \quad (9)$$

Na kraju potrebno je izračunati površinu krova P_k koji će se mijenjati. Kraća stranica kvadrata krova jednaka korijenu zbroja kvadrata razlike u visinama objekta (visine po centru H_c i visine po rubu H_r) i polovine širine zgrade W . Duža stranica kvadrata kriva jednaka je dužini zgrade L . Ta kvadrata su dva i jednaka su po površini. Formula za računanje površine krova glasi:

$$P_k = 2 \cdot \sqrt{(H_c - H_r)^2 + \left(\frac{W}{2}\right)^2} \cdot L. \quad (10)$$

Kako bi se dobile tražene površine podatci iz Tablice 2. uvrštavaju se u formule (od 5 do 10). Postupak je ponovljen za sva četiri mjerenja a dobiveni su rezultati prikazani u Tablici 3.

Tablica 3. Proračun površina objekta za obnovu

	S_1	S_2	S_3	S_4
$P_{zo} [m^2]$	584,20	563,1	539,49	479,55
$P_v [m^2]$	35,71	37,69	38,88	30,68
$P_p [m^2]$	56,43	61,92	65,36	41,17
$P_{pp} [m^2]$	16,18	13,7	15,97	13,35
$P_{puk} [m^2]$	72,61	75,62	81,33	54,52
$P_{vv} [m^2]$	118,16	129,1	118	121,95
$P_z [m^2]$	357,72	320,69	301	272,4
$P_k [m^2]$	654	628,96	617,91	477,18

Ovim su dobivena rješenja problemskog zadatka iz četiri različita mjerenja. Ona su:


- Površina zida P_z ;
- Površina vrata P_v ;
- Površina prozora P_p ;
- Površina vrata za vozila P_{vv} ;
- Površina krova P_k .

6. STATISTIČKA ANALIZA POGREŠKE I USPOREDBA REZULTATA MJERENJA I STVARNIH VRIJEDNOSTI

6. 1. Greške u mjerenju stereoskopskom paralaksom

Na točnost mjerenja stereoskopskom paralaksom snimanjem iz zraka utječu razni faktora. Prvi i najvažniji faktor je računanje visine na kojoj su fotografije snimljene. Visinu leta kod vertikalnog snimanja je teže precizno odrediti od horizontalnih udaljenosti kod mjerenja na zemlji. Na relativno maloj visini od 10 m greška od 1 m može unijeti velika odstupanja u izračun. Kako bi se problem riješio potrebno je osigurati točno mjerenje visine. Najbolje rješenje je imati više neovisnih sustava mjerenja visine. Ti sustavi uključuju GPS, radio visinomjer, barometarski visinomjer i slično.

Drugi faktor točnosti je nagib kamere u odnosu na površinu. Idealno snimanje vrši se pod kutom od 90° na ravninu snimanja. Odnosi ravnine nagnute fotografije i idealne okomite fotografije prikazani su na Slici 34. S porastom odstupanja od toga kuta raste i greška. Ona također raste s udaljenošću objekta od centra fotografije. Kut nagiba kamere od 5° na visini leta od 500 m i kamerom kuta vidljivosti od 120° može prouzročiti grešku u izračunanju visine do 40 m, odnosno 8 %. Iz toga razloga kamere se pričvršćuju na posebne nosače koje balansiraju žiroskopi. Time usmjerenje kamere nije više ovisno o nagibu i podrhtavanju zrakoplova.



Slika 34. Nagib nagnute fotografije u odnosu na ravninu idealne okomite fotografije

Treća grupa grešaka nastaje tijekom samog mjerenja. U odnosu na veličinu objekta iz prošlih poglavlja visine i udaljenosti snimanja su relativno male. To čini objekt na fotografijama većim. U slučaju snimanja s velikih udaljenosti objekti postaju sve manji što otežava računanje diferencijske paralakse. Te mjere postaju toliko sitne da ih se više ne može mjeriti ručno. Takve fotografije je potrebno analizirati digitalno.

Nadalje greške mogu nastati zbog kvalitete kamere. Ako je rezolucija kamere mala udaljene objekte bit će teško razlučiti od okoline. Time se povećava vjerojatnost greške u mjerenju udaljenosti baza i vrhova. Stoga je potrebno osigurati kvalitetnu kameru za snimanje.

6. 2. Statistička analiza pogreške

U prošlom poglavlju računskim putem dobiveni su rezultati mjerenja x_i koji zbog raznih utjecaja mogu odstupati od stvarnih vrijednosti X . Odstupanje pojedine izmjerene vrijednosti od prave vrijednosti naziva se pogreškom mjerenja Δx :

$$\Delta x = x_i - X. \quad (11)$$

Postoje 3 vrste pogreški mjerenja; grube, sistematske i slučajne. Grube pogreške nastaju iznenadnim poremećajima u okolini ili mjernom uređaju. One nastaju i zbog propusta u mjerenju kao što je pogrešno iščitavanje vrijednosti ili bilježenje rezultata. One su drastične i potrebno ih je odbaciti a mjerenje ponoviti. Drugi tip pogrešaka su sistematske greške. One uključuju pogreške uzrokovane mjernim uređajem ili tehnikom. Njihova glavna karakteristika je da se ponavljaju u smjeru i iznosu. One radi svoje konstantnosti nisu dio statističke analize jer ih posjeduje svaki dobiveni rezultat. Kako bi se osiguralo što točnije mjerenje potrebno je poboljšati mjerne instrumente i tehniku mjerenja. Posljednji tip pogrešaka su slučajne pogreške. One su neizbježne i ponavljanjem mjerenja dobivaju se različiti rezultati. One su slučajne po iznosu i smjeru i mogu se statistički obraditi. Uzrokovane su preciznošću mjernog uređaja kao i tehnikom mjerenja. Dva načina smanjivanja ovog tipa pogrešaka su izoliranje mjerenja i usavršavanje mjernih uređaja i tehnike. Što je više mjerenja lakše je doći do prave vrijednosti. Prethodno navedene greške u poglavlju 6. 1. spadaju u kategoriju slučajnih grešaka.

Prvi korak analize rezultata mjerenja iz prošlog poglavlja je odrediti \bar{x} srednje. Ona se izračunava kao aritmetička sredina n broja mjerenja i glasi:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i . \quad (12)$$

Uzima se da je upravo srednja vrijednost \bar{x} najvjerojatnija prava vrijednost X . Ona je očekivana vrijednost mjerenja. Sljedeći korak analize pogreške jest srednja kvadratna pogreška mjerenja, odnosno standardna devijacija. Ona je pokazatelj pouzdanosti pojedinog mjerenja. Pokazuje rasipanje rezultata kao posljedicu preciznosti uređaja i tehnike mjerenja. Za velik broj mjerenja poprima ustaljenu vrijednost. Formula za standardnu devijaciju glasi:

$$m = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} . \quad (13)$$

Moguće je izmjeriti u kojoj je mjeri dobiveni rezultat nepouzdan. Nepouzdanost mjerenja se računa kao kvadratna pogreška aritmetičke sredine, odnosno standardne pogreške. Nepouzdanost je samo za faktor $1/\sqrt{n}$ manja od standardne devijacije m . Značajno manja standardna pogreška može se dobiti izvođenjem većeg broja mjerenja:

$$M_n = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n(n-1)}} , \quad (14)$$

$$M_{n=\frac{m}{\sqrt{n}}} . \quad (15)$$

Vjerojatnost da se neki izmjereni podatak X nalazi u intervalu $\bar{x} - M_n \leq X \leq \bar{x} + M_n$, to jest unutar jedne standardne devijacije iznosi 68,3%. Vjerojatnost da se nalazi unutar 3 standardne devijacije je 99,9 %. Nepouzdanost rezultata mjerenja moguće je izraziti u postotku kao relativnu nepouzdanost mjerenja. Ona glasi:

$$R = \frac{M_n}{\bar{x}} \cdot 100 \%. \quad (16)$$

Kada se ova statistička analiza primjeni na dobivene vrijednosti za ključne površine objekta dobivaju se rezultati prikazani u Tablici 4.

Tablica 4. Rezultati statičkr analize površina

	S_1	S_2	S_3	S_4	\bar{x}	m	M_n	R [%]
$P_z [m^2]$	357,72	320,69	301	272,4	312,95	35,82	17,91	5,72
$P_v [m^2]$	35,71	37,62	38,88	30,68	35,72	3,6	1,8	5,03
$P_{puk} [m^2]$	72,61	75,62	81,33	54,52	71,02	10,57	5,78	8,13
$P_{vv} [m^2]$	118,16	129,1	118	121,95	121,8	5,19	2,95	2,42
$P_k [m^2]$	654	628,96	617,91	477,18	594,51	79,66	39,83	6,69

6. 3. Usporedba rezultata mjerenja i stvarnih dimenzija

Za usporednu računski dobivenih veličina potrebno je imati stvarne dimenzije objekta. Manje dimenzije kao što su visina vrata i širina prozora mjerene su ručno metrom. Širina i duljina zgrade izmjerene su alatom za mjerenje u programu Google earth. Stvarne veličine su prikazane u Tablici 5.

Tablica 5. Stvarne veličine objekta

Širina [m]	Dužina [m]	Visina po sredini [m]	Visina po rubu [m]	Širina vrata [m]	Visina vrata [m]
20	30	6,60	5,10	1	2,20

Širina prozora [m]	Visina prozora [cm]	Širina potkrovnog prozora [m]	Visina potkrovnog prozora [m]	Širina vrata za vozila [m]	Visina vrata za vozila [m]
1	70	12	1,20	4	5,1

Uvrste li se vrijednosti iz Tablice 5. u formule za dobivanje površina (od 5 do 10) dobivaju se stvarne vrijednosti površina (Tablica 6.).

Tablica 6. Vrijednosti stvarnih površina objekta

Stvarna površina zida [m ²]	Stvarna površina vrata [m ²]	Stvarna površina prozora [m ²]	Stvarna površina vrata za vozila [m ²]	Stvarna površina krova [m ²]
329,2	35,2	67,6	122,4	607,2

Kako bi se dobila apsolutna pogreška stvarne i izmjerene vrijednosti će se uvrstiti u formulu:

$$\Delta x = |x_i - X|. \quad (17)$$

Za dobivene apsolutne razlike će se računati srednja vrijednost i standardno odstupanje, odnosno devijacija. Varijanca s^2 računati će se prema sljedećoj formuli:

$$s^2 = \frac{\sum_{i=1}^n (x_i - X)^2}{n}. \quad (18)$$

Također izdvojiti će se ekstremi, odnosno minimalno i maksimalno odstupanje Δx_{\min} i Δx_{\max} .

Tablica 7. Statistička analiza pogreške mjerenja u odnosu na stvarnu vrijednost


	S_1	S_2	S_3	S_4	\bar{x}	m	s^2	Δx_{\min}	Δx_{\max}
$\Delta P_z [\text{m}^2]$	28,52	8,51	28,2	56,8	30,5	21,89	479,26	8,51	56,8
$\Delta P_v [\text{m}^2]$	0,51	2,42	3,68	5,48	3,02	2,09	4,38	0,51	5,48
$\Delta P_{\text{puk}} [\text{m}^2]$	5,01	8,02	13,73	13,08	9,96	4,17	17,4	5,01	13,73
$\Delta P_{vv} [\text{m}^2]$	4,24	6,7	4,4	0,45	3,94	2,58	6,69	0,45	6,7
$\Delta P_k [\text{m}^2]$	46,8	21,76	10,71	130,02	52,32	53,59	2911,02	10,71	130,02

Na samom kraju greška u mjerenju izraziti će se postotkom odstupanja od stvarne vrijednosti prema formuli:

$$R\Delta x = \frac{|x_i - X|}{X} \cdot 100 \%. \quad (19)$$

Tablica 8. Relativna odstupanja izmjerenih vrijednosti u odnosu na stvarne

	S_1	S_2	S_3	S_4
$R_{\Delta Pz}$ [%]	8,66	2,58	8,56	17,25
$R_{\Delta Pv}$ [%]	1,44	6,87	10,45	15,56
$R_{\Delta P_{puk}}$ [%]	7,41	11,86	20,31	19,34
$R_{\Delta P_{vv}}$ [%]	3,46	5,47	3,59	0,36
$R_{\Delta Pk}$ [%]	7,7	3,58	1,76	21,41



Slika 35. Grafički prikaz relativna odstupanja grupiranih po površinama

Radi lakše usporedbe rezultati iz Tablice 8. prikazani su grafički na Slici 35.

Na Slici 35. vidljivo je da su najmanja odstupanja u površini vrata za vozila kreću se od 0,36 % do 5,47 %. Iako je najveće odstupanje od 21,41 % prisutno u mjerenju krova najveća odstupanja za sva mjerenja prisutna su u računanju površine prozora. Razlog tome je broj veličina koje ulaze u izračun. Vrata za vozila imaju samo dvije, dok prozori četiri. Svaka se dimenzija množi kako bi se dobile površine, time se množe i greške. Najmanja odstupanja za sve površine prisutna su u prvom mjerenju i kreću se od 1,44 % do 8,66 %. najveća odstupanja prisutna su u četvrtom mjerenju. Od 5 izmjerenih površina čak 4 imaju odstupanja veća od 15 %. Kod manjih visina i horizontalnih udaljenosti objekt je na fotografiji veći i lakše ga je mjeriti. S povećanjem udaljenosti objekt se smanjuje i teže je precizno izmjeriti dimenzije.

7. ZAKLJUČAK

Snimanje iz zraka i računanje visina iz tih fotografija danas ima široku primjenu u mnogim industrijama i znanostima. Paralaksa se koristi za mapiranje nepristupačnih terena kao i za računanje udaljenosti među dalekim zvijezdama. Primjenom te iste paralakse riješen je problemski zadatak određivanja parcijalnih površina derutnog objekta namijenjenog za obnovu na kampusu Borongaj.

Izmjerene osnovne vrijednosti poput visine vrata i širine prozora vrlo su bliske stvarnim. Iz tih dobivenih veličina proračunate su površine. Kod površina dolazi do znatnog povećanja odstupanja. Uzme li se za primjer četvrto mjerenje u kojem su izmjerena širina zgrade 17,26 m i dužina 27,33 m. Odstupanja od svega desetak posto rastu i do dvadeset posto u računu za površinu. Tome je razlog višestruko množenje visine i širine. Od stvarnih površina najmanje odstupa površina vrata za vozila. Minimalno odstupanje je 0,36 % a maksimalno 5,47 %. Širina vrata za vozila i visina zgrade po rubu relativno su točno proračunate paralaksom. Najveća odstupanja pojavljuju se kod ukupne površine prozora. Ona iznose od 7,14 % do 19,34 %. Razlog tomu je veliki broj varijabli koji ulazi u izračun površine. Dok vrata za vozila imaju samo dvije dimenzije za ukupnu površinu prozora trebalo je mjeriti širinu i visinu prozora kao i visinu i širinu potkrovnog prozora. Može se zaključiti da što je više veličina uključeno u računanje greška postaje veća. Prvo mjerenje za sve tri dimenzije izvedeno je najbliže objektu, visina i horizontalna udaljenost bile su najmanje. Odstupanja u prvom mjerenju kreću se od 1,44 % do 8,66 %. Greške četvrtog mjerenja su puno veće. Osim greške u površini vrata za vozila one se kreću od 15,56 % do 21,41 %. Greška raste sa udaljavanjem od objekta. Što je visina ili horizontalna udaljenost od objekta manja to je objekt na fotografiji veći, što na kraju znači lakše i točnije mjerenje paralaksom.

Ovaj je izračun pokazao da se stereoskopska paralaksa može koristiti na praktičnom primjeru obnove objekta. Odstupanja od stvarnih vrijednosti mogu se smanjiti povećanjem broja mjerenja, kao i preciznijim mjerenjem i određivanjem udaljenosti.

LITERATURA

- [1] James B. Campbell, Randolph H. Wynne: Introduction to remote sensing, fifth edition, A Division of Guilford Publications, Inc., New York, 2011
- [2] The Canada centre for Mapping and Earth Observation: Fundamentals of Remote Sensing, Canada, 2016 ,available at <https://www.nrcan.gc.ca/node/9309> (downloaded on 1st of April 2018)
- [3] C. H. Chen: Signal and Image Processing for Remote Sensing, Taylor and Francis Group, Broken Sound Parkway NW, United States of America, 2007
- [4] R. C. Olsen: Remote Sensing from Air and Space, SPIE - The International Society for Optical Engineering, Bellingham, Washington, United States of America, 2007
- [5] Noam Levin: Fundamentals of Remote Sensing, International Maritime Academy, Trieste, Italy, 1999
- [6] M. Anji Reddy: Remote Sensing and Geographical Information Systems, third edition BS Publications, Kukatpally, India, 2008
- [7] Cornell University Library, Research Department (prepared by Anne R. Kenney, Oya Y. Rienger, Richard Entlich), Moving Theory into Practice - Digital Imaging Tutorial, New York, United States of America, 2003
- [8] Edward M. Purcell, David J. Morin, Electricity and Magnetism, third edition, Cambridge University Press, United States of America, New York, 2013
- [9] M. Makek, Prirodoslovno matematički fakultet, Izračun pogreške, Statistika i osnova mjerenja, Zagreb, 2017, preuzeto <http://www.phy.pmf.unizg.hr/~makek/som/predavanja/1%20Racun%20pogreske.pdf> (preuzeto 5. rujna 2018.)

POPIS SLIKA

Slika 1. Električno i magnetsko polje EM vala [2]	2
Slika 2. Karakteristične veličine elektromagnetskog zračenja.....	3
Slika 3. Podjela elektromagnetskog spektra.....	4
Slika 4. Reflektirano zračenje u području vidljive svjetlosti [1]	5
Slika 5. Bojenje fotografije u infracrvenom području [2]	6
Slika 6. Dijelovi analogne kamere [1]	7
Slika 7. Senzor prima sunčevo reflektirano zračenje [1]	8
Slika 8. Senzor prima infracrveno (termalno) zračenje od zemlje [1]	9
Slika 9. Zračenje napušta zrakoplov, odbija se i vraća natrag prema senzoru [1].....	9
Slika 10. Klasifikacija usjeva, sećerna trska (S), pšenica (W), kukuruz (C) i neobrađena zemlja (F) [1].	11
Slika 11. Refleksivnost drveća i lista [2].....	11
Slika 12. Različite razine reflektivnosti u bliskom infracrvenom području za travu, drveća širokih listova i igličastih drveća [2]	12
Slika 13. Fotoklinometrija [1]	13
Slika 14. Praćenje erozije obale uslijed morskog djelovanja [1].....	14
Slika 15. Koraci u procesu mapiranja [1]	15
Slika 16. Perspektive fotografija iz zraka	17
Slika 17. Prekapanje fotografija snimljenih iz zraka	18
Slika 18. Fotografiranje iz zraka tijekom topografskog mapiranja	19
Slika 19. Razlika u percepciji lijevog i desnog oka	19
Slika 20. Stereoskopska paralaksa	21
Slika 21. Mjerenje visine zastavice stereoskopskom paralaksom	21
Slika 22. Napušteni vojni objekt na kampusu Borongaj; Izvor: Google Earth, kolovoz 2018.....	23
Slika 23. Aproksimacija površina prednje strane objekta	24
Slika 24. Aproksimacija površina bočne strane objekta	24
Slika 25. Ključne veličine za rješavanje problemskog zadatka	26
Slika 26. Planirani parovi prednjeg snimanja	26
Slika 27. Planirani parovi bočnog snimanja	27
Slika 28. Planirani parovi vertikalnog snimanja.....	27
Slika 29. Bepilotna letjelica ustupljen od strane fakulteta prometnih znanosti	28
Slika 30. Računanje visine leta bepilotne letjelice u programu Mission PLanner.....	29
Slika 31. Mjerenje visine zgrade primjenom stereoskopske paralakse na fotografijama dobivenim snimanjem iz zraka	29
Slika 32. Udaljenosti pravaca snimanja objekta za dobivanje horizontalnih dimanzija	30
Slika 33. Mjerenje duljine zgrade primjenom stereoskopske paralakse na fotografijama dobivenim horizontalnim snimanjem	31
Slika 34. Nagib nagnute fotografije u odnosu na ravninu idealne okomite fotografije	37
Slika 35. Grafički prikaz relativna odstupanja grupiranih po površinama	43

POPIS TABLICA

Tablica 1. Vrijednosti dobivene stereoskopskom paralaksom	32
Tablica 2. Veličine proračunate iz veličina dobivenih stereoskopskom paralaksom	33
Tablica 3. Proračun površina objekta za obnovu.....	35
Tablica 4. Rezultati statičkr analize površina.....	40
Tablica 5. Stvarne veličine objekta	41
Tablica 6. Vrijednosti stvarnih površina objekta	41
Tablica 7. Statistička analiza pogreške mjerenja u odnosu na stvarnu vrijednost	42
Tablica 8. Relativna odstupanja izmjerenih vrijednosti u odnosu na stvarne.....	43

PRILOZI



Prilog 1. Parovi fotografija mjerenja visina objekta

Vertikalne slike snimljene su u istoj rezoluciji kao i horizontalne. Tijekom obrade u programu GoPro kamere došlo je do smanjivanja visina slike.



Unutarnji par fotografija snimljenih na visini od 10,5 m, prvo mjerenje.





Vanjski par fotografija snimljenih sa 10,5 m, drugo mjerenje.



Unutarnji par fotografija snimljenih sa 14,5 m, treće mjerenje.



Vanjski par fotografija snimljenih sa 14,5 m. Četvrto mjerenje.



Prilog 2. Parovi fotografija mjerenja širine objekta

Unutarnji par fotografija snimljen na udaljenosti od 38 m, prvo mjerenje.



Vanjski par fotografija snimljenih s udaljenosti od 38 m, drugo mjerenje.



Unutarnji par fotografija snimljen sa udaljenosti od 53,5 m, treće mjerenje.



Vanjski par fotografija snimljen na udaljenosti od 53,5 m, četvrto mjerenje.



Prilog 3. Parovi fotografija mjerenja dužina objekta

Unutarnji par fotografija snimljen na udaljenosti od 46 m, prvo mjerenje.



Vanjski par fotografija snimljen na udaljenosti od 46 m, drugo mjerenje.



Unutarnji par fotografija snimljen na udaljenosti od 58 m, treće mjerenje.



Vanjski par fotografija snimljen na udaljenosti od 58 m, četvrto mjerjenje.





Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj _____ diplomski rad

isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu _____ diplomskog rada
pod naslovom **Određivanje dimenzija objekta snimljenog iz zraka**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, _____ 09-19-18 _____

(potpis)